

LSB embedding

LSB 1

• Nosič $x = (x_1, \dots, x_n) \in \mathbb{Z}^n$

např. x = intenzita jasu určitého pixelu

x_i = intenzita červené složky určitého pixelu

index do palety v obraze GIF

kvantizovaný DCT koeficient

• Stegoobjekt $y = (y_1, \dots, y_n) \in \mathbb{Z}^n$

• Zpráva $z = (z_1, \dots, z_m) \in \{0, 1\}^m$, kde $m \leq n$.

• Klíč $\pi \in S_n$

• Vkládání:

$$y_{\pi(i)} = x_{\pi(i)} - (x_{\pi(i)} \bmod 2) + z_i \quad \text{pro } i=1, \dots, m.$$

$$y_{\pi(i)} = x_{\pi(i)} \quad \text{pro } i=m+1, \dots, n.$$

• Platí $|x_i - y_i| \leq 1 \quad \forall i$ (t_j provádí nejmenší možnou změnu).

LSB rovina nekompromisovaných obrazů vypadá vesměs vhodně kvůli sumě při snímání obrazu. Vložení vhodné zprávy by tedy zřejmě nemělo být detekovatelné. Ve skutečnosti existují mezi sousedními pixely vztahy, které jsou tímto vkládáním narušeny.

• Platí $x_i \in \{2k, 2k+1\} \Leftrightarrow y_i \in \{2k, 2k+1\}$ čili: $0 \xrightarrow{1} 1 \quad 2 \xrightarrow{3} 3 \quad 4 \xrightarrow{5} 5 \quad -2 \xrightarrow{-1} -1$

• Tato vlastnost se projeví v histogramu.

Definujeme $h_0(v) = \#\{i \mid x_i = v\}$ histogram nosiče

$h(v) = \#\{i \mid y_i = v\}$ histogram stegoobjektu

Platí $h(2k) + h(2k+1) = h_0(2k) + h_0(2k+1)$.

• Označme $\alpha = m/n$ a předpokládejme, že vkládáme vhodnou zprávu, potom

$$P(y_i \neq x_i) = \alpha \cdot \frac{1}{2}$$

$\uparrow$ pravděpodobnost, že daný pixel obsahuje bit zprávy

pravděpodobnost, že vložený bit se liší od původního LSB.

$$P(y_i = x_i) = 1 - \alpha/2$$

$$E[h(2k)] = \left(1 - \frac{\alpha}{2}\right) h_0(2k) + \frac{\alpha}{2} h_0(2k+1) \quad (*)$$

$$E[h(2k+1)] = \frac{\alpha}{2} h_0(2k) + \left(1 - \frac{\alpha}{2}\right) h_0(2k+1)$$

Histogramový útok na úplný LSB embedding.

Jestliže $\alpha = 1$ pak pro všechna k

$$E[h(2k)] = E[h(2k+1)] = \frac{h_0(2k) + h_0(2k+1)}{2} = \frac{h(2k) + h(2k+1)}{2} =: \bar{h}(2k)$$

$$\text{Čili } h(2k) \approx \bar{h}(2k).$$

Máme-li rozhodnout, zda $\alpha = 1$ nebo $\alpha < 1$ testujeme hypotézu, že h má rozdělení $\bar{h}$:

$$H_0: h \sim \bar{h} \quad (\text{nulová hypotéza}) \quad \alpha = 1$$

$$H_1: h \not\sim \bar{h} \quad (\text{alternativní hypotéza}) \quad \alpha < 1$$

• Použijeme Pearsonův χ^2 test. Spočítáme statistiku S :

$$S = \sum_{k=0}^{d-1} \frac{(h(2k) - \bar{h}(2k))^2}{\bar{h}(2k)}$$


např. $d = 128$

jeť myslím, že $d-1 = 127$

• Je zřejmé, že velká hodnota S indikuje $h \not\sim \bar{h}$ čili $\alpha < 1$, ale co znamená „velká hodnota“?

• Jestliže $\bar{h}(2k) > 4 \forall k$ a platí $h \sim \bar{h}$, pak S má ^{relativně} přibližně rozdělení χ^2_{d-1} s danou stupni volnosti.

• Hustota pravděpodobnosti rozdělení χ^2_{d-1} je $f_{\chi^2_{d-1}}(x) = \frac{e^{-x/2} x^{\frac{d-1}{2}-1}}{2^{\frac{d-1}{2}} \Gamma(\frac{d-1}{2})}$



Čili $p = \int_S^\infty f_{\chi^2_{d-1}}(x) dx$ je pravděpodobnost, že S dosáhne takto vysoké (nebo vyšší) hodnoty za předpokladu $h \sim \bar{h}$.

Je-li $p \leq 0.05$ (např.) pak nulovou hypotézu zamítneme a řekneme, že „zamítáme H_0 (tj. $\alpha = 1$) na hladině významnosti 0.05“.

$$\text{Čili: } (S > 154.3) \Rightarrow \alpha < 1$$

$$(S < 154.3) \Rightarrow \alpha = 1$$

(pravděpodobnost, že zamítneme $\alpha = 1$ ačkoliv $\alpha = 1$)
pravděpodobnost, že chybně zamítneme hypotézu $\alpha = 1$ je 5%.

• Známe-li π , můžeme odhadnout hodnotu α . Budeme provádět statistiku na $(x_{\pi(1)}, \dots, x_{\pi(n)})$ pro $i = 1, \dots, n$ a počítat hodnotu p :



Kvantitativní vložek na Jsteg

kvantitativní = úroveň α

LSB3

- Jsteg vkládá zprávu do LSB DCT koeficientů obrázku JPEG, s výjimkou koeficientů s hodnotami 0 a 1.
Vkládání do 0 se totiž projeví vizuálně.

- Víme, že DCT koeficienty v JPEGu mají symetrický histogram

$$h_0[i] \approx h_0[-i] \quad i=1,2,\dots$$

proto platí

$$\sum_{k>0} h_0(2k) - \sum_{k<0} h_0(2k) - \sum_{k>0} h_0(2k+1) + \sum_{k<0} h_0(2k+1) \approx 0 \quad (F)$$

$\downarrow 1,3,5,\dots$ $\downarrow -1,-3,-5,\dots$

- Soustavu lineárních rovníc (*) na stránce 2 můžeme přepsat:

$$h_0(2k) = a E[h(2k)] - b E[h(2k+1)]$$

$$h_0(2k+1) = -b E[h(2k)] + a E[h(2k+1)] \quad \text{pro } k \neq 0! \text{ protože do } \{0,1\} \text{ nevházíme.}$$

$$\text{kde } a = \frac{1-\alpha/2}{1-\alpha}, \quad b = \frac{\alpha/2}{1-\alpha}$$

- Provedeme aproximaci $h(i) \approx E[h(i)]$ a dosadíme do (F).

$$\begin{aligned} \sum_{k>0} a h(2k) - b h(2k+1) - \sum_{k<0} a h(2k) - b h(2k+1) \\ - \sum_{k>0} -b h(2k) + a h(2k+1) + \sum_{k<0} -b h(2k) + a h(2k+1) \approx h_0(1) = h(1) \end{aligned}$$

pozor k=0 přesouváme na pravou stranu. ↑ do koef. 1 se nevházíme

$$(a+b) \sum_{k>0} h(2k) - h(2k+1) + (a+b) \sum_{k<0} h(2k+1) - h(2k) \approx h(1)$$

$$a+b = \frac{1}{1-\alpha}$$


- Vyřešíme α :
$$\alpha \approx 1 - \frac{\sum_{k>0} h(2k) - h(2k+1) + \sum_{k<0} h(2k+1) - h(2k)}{h(1)}$$

α obvykle vychází s přesností ± 0.05

Sample pairs analysis (Analýza dvojic vzorků)

LSB4

- Princip histogramového útoku:




funguje pro $\alpha=1$ vs $\alpha \neq 1$


Pro obecné α bychom potřebovali vědět více o tvaru histogramu nosiče. Problém je v tom, že histogramy nosičů jsou příliš rozmanité na to, abychom mohli vypracovat nějakou obecnou vlastnost.

- Podíváme se na páry sousedních pixelů.

V přirozeném obraze očekáváme, že sousední pixely budou mít blízké hodnoty. Například:




vs.



méně častý výskyt

častější výskyt

co se stane při LSB:



(Výskyt se vyváží.)

Ide v podstatě o to, že histogram párů sousedních pixelů má předvídatelný tvar. Přesněji jde o to, že v nosiči by výskyt těchto čtyř párů neměl být nelineární.

- Obecně: Máme četverice párů; jak vypadají jejich rozdíly?

	$(2i, 2j)$	$(2i, 2j+1)$	$(2i+1, 2j)$	$(2i+1, 2j+1)$
$i < j$	$d \times$	$d+1 \gamma_1$	$d-1 \times$	$d \gamma_1$
$i > j$	$d \gamma_1$	$d-1 \times$	$d+1 \gamma_1$	$d \times$
$i = j$	0^2	$1 \gamma_2$	$1 \gamma_2$	0^2

$d = 2j - 2i$

$d = 2i - 2j$

BTW: nulové vzdálenosti se objevují pouze v 2 jednotkových jednách v γ_2 jednách v $\times$!!!

- Nechť P je množina všech párů sousedních pixelů.

$$X = \{(r, s) \in P \mid (r < s \wedge s \text{ sudé}) \vee (r > s \wedge s \text{ liché})\}$$

$$Y = \{(r, s) \in P \mid (r < s \wedge s \text{ liché}) \vee (r > s \wedge s \text{ sudé})\}$$

$$Z = \{(r, s) \in P \mid r = s\}$$

(Jedná se o multimnožinu.)

Pro nosič platí $|X| \approx |Y|$, protože je-li $r < s$ pak s může být sudé nebo liché s pravděpodobností 50:50.

Ve skutečnosti je Y o trochu větší než X , ale při dostatečném počtu barev (odstínech) můžeme zanedbat. Pro 4 barvy: $\#$ typů párů v X je $\frac{n^2}{2} - n$ a v Y je $\frac{n^2}{2}$. Většina nadbytečných párů v Y má nulou pravděpodobnost výskytu.

X	γ_1	γ_2	Z
(0, 2)	(0, 3)	(0, 1)	(0, 0)
(1, 2)	(1, 3)	(1, 0)	(1, 1)
(2, 1)	(2, 0)	(2, 3)	(2, 2)
(3, 1)	(3, 0)	(3, 2)	(3, 3)

Mimo chodem pro stegoobjekt je $|Y| > |X|$ resp. $E[|X| - |Y|] < 0$. LSB 5

Ide o to, že při vkládání se množiny X a Y_1 využívají a množiny Y_2 a Z se využívají.

Konkrétně pro $\alpha=1$ a $r \leq s$, je-li $|r-s| > 1$ pak opět pravděpodobnost, že s je sudé vs. liché je 50:50, ale je-li $|r-s|=1$ pak s je liché.


Definujeme $Y_1 = Y \setminus Y_2$

$$Y_2 = \{(r, s) \in P \mid r=2k, s=2k+1 \text{ nebo } r=2k+1, s=2k\}$$

Co se může stát s (r,s) při vkládání:

- 1) Nezmění se = změna 00.
- 2) Změní se jen r = změna 10.
- 3) Změní se jen s = změna 01.
- 4) Změní se oba = změna 11.

Pozor! Pro Y_2 a Z platí i to
pro X a Y_1 platí i to



Označme β pravděpodobnost změny LSB při vkládání, tj:
 $\beta := \alpha/2$

dále označme množiny, které vzniknou vkládáním X', Y_1', Y_2', Z' .

$$|X'| \approx (1-\beta)|X| + \beta|Y_1|$$

$$|Y_1'| \approx (1-\beta)|Y_1| + \beta|X|$$

$$\left. \begin{aligned} |X'| &\approx (1-\beta)|X| + \beta|Y_1| \\ |Y_1'| &\approx (1-\beta)|Y_1| + \beta|X| \end{aligned} \right\} \textcircled{1} |X'| - |Y_1'| = (1-2\beta)(|X| - |Y_1|)$$

$$|Y_2'| \approx (1-2\beta+2\beta^2)|Y_2| + 2\beta(1-\beta)|Z|$$

$$|X| \approx |Y| = |Y_1| + |Y_2|$$

$$|Y_2| + |Z| = |Y_2'| + |Z'|$$

$$\Rightarrow |Z| = |Y_2'| + |Z'| - |Y_2|$$

$$|P| = |X'| + |Y_1'| + |Y_2'| + |Z'|$$

(Čárkované známe, nečárkovaných se chceme zbavit a zůstat β)

Z těchto rovnic dostaneme

$$2(|Y_2'| + |Z'|)\beta^2 + 2(2|X'| - |P|)\beta + |Y_1'| - |X'| = 0$$

$$\beta = \frac{1}{2} \left(1 - \frac{|X'| - |Y_1'|}{|Z'| + |Y_2'|} \pm \sqrt{\left(\frac{|X'| - |Y_1'|}{|Z'| + |Y_2'|} \right)^2 + \frac{|Z'| - |Y_2'|}{|Z'| + |Y_2'|}} \right)$$

(X obvykle vychází s přesností 0.05)

Očekáváme $|X'| \geq |Y_1'|$ a $|Z'| \geq |Y_2'|$. V takovém případě je $\beta_- \leq 0.5$ a $\beta_+ \geq 0.5$.


Bereme tedy $\text{Re}(\beta_-)$. (Vkládáme-li hodně dat, tj. β blízko 0.5, může výraz pod odmocninou vyjít záporný. V takovém případě ho zanedbáme tím že vezmeme Re)

- Označme $A_k = \{(2i, 2j) \in P \mid i-j=k\}$
 $B_k = \{(2i, 2j+1) \in P \mid i-j=k\}$
 $C_k = \{(2i+1, 2j) \in P \mid i-j=k\}$
 $D_k = \{(2i+1, 2j+1) \in P \mid i-j=k\}$

Multimnožiny

Kde P je multimnožina všech párů sousedících pixelů.

- Co se stane při vkládání:



Označme a_k, b_k, c_k, d_k velikosti multimnožin A_k, B_k, C_k, D_k a a'_k, b'_k, c'_k, d'_k jejich velikosti po vkládání. Potom

$$\begin{pmatrix} a'_k \\ b'_k \\ c'_k \\ d'_k \end{pmatrix} \approx \begin{pmatrix} (1-\beta)^2 & \beta(1-\beta) & \beta(1-\beta) & \beta^2 \\ \beta(1-\beta) & (1-\beta)^2 & \beta^2 & \beta(1-\beta) \\ \beta(1-\beta) & \beta^2 & (1-\beta)^2 & \beta(1-\beta) \\ \beta^2 & \beta(1-\beta) & \beta(1-\beta) & (1-\beta)^2 \end{pmatrix} \begin{pmatrix} a_k \\ b_k \\ c_k \\ d_k \end{pmatrix}$$

$$\rightarrow \begin{pmatrix} a_k \\ b_k \\ c_k \\ d_k \end{pmatrix} \approx \frac{1}{1-2\beta} \begin{pmatrix} (1-\beta)^2 & -\beta(1-\beta) & -\beta(1-\beta) & \beta^2 \\ -\beta(1-\beta) & (1-\beta)^2 & \beta^2 & -\beta(1-\beta) \\ -\beta(1-\beta) & \beta^2 & (1-\beta)^2 & -\beta(1-\beta) \\ \beta^2 & -\beta(1-\beta) & -\beta(1-\beta) & (1-\beta)^2 \end{pmatrix} \begin{pmatrix} a'_k \\ b'_k \\ c'_k \\ d'_k \end{pmatrix} \leftarrow$$

$$B_k = \{(2i, 2j+1) \in P \mid i-j=k\} \text{ vzdálenost: } 2i - (2j+1) = 2k-1$$

$$C_{k-1} = \{(2i+1, 2j) \in P \mid i-j=k-1\} \text{ vzdálenost: } 2i+1-2j = 2(k-1)+1 = 2k-1$$

Očekáváme, že v nosiči platí $|B_k| \approx |C_{k-1}|$ protože páry v obou třídách se mají vzdálenost $2k-1$ a liší se pouze paritou. Parita by v nosiči neměla mít vliv na četnost.

- Podíváme-li se na 2. a 3. řádek soustavy dostáváme pro každé k kvadratickou rovnici:

$$\frac{1}{1-2\beta} \left(\beta^2 (a'_k + b'_k + c'_k + d'_k) - \beta (a'_k + 2b'_k + d'_k) + b'_k \right) \approx b_k$$

$$\frac{1}{1-2\beta} \left(\beta^2 (a'_{k-1} + b'_{k-1} + c'_{k-1} + d'_{k-1}) - \beta (a'_{k-1} + 2c'_{k-1} + d'_{k-1}) + c'_{k-1} \right) \approx c_{k-1}$$

$1-2\beta$ se odstraní a zůstane kvadratická rovnice

Mimochodem $|A_k| \approx |D_k|$ se využít nedá, pouze to implikuje že $|A'_k| \approx |D'_k|$ v B.

Jak nalozit s touto sadou kvadratických rovnic?

LSB7

- 1) Pro např. $i = -2, -1, 0, 1, 2$ najde kořeny kvadratické rovnice a z nich vybere minimální.
- 2) Kvadratické rovnice sečtu pro všechna i sudá nebo pro i lichá, dostanu jednu rovnici a tu vyřeším.
(Kdybych sečetl přes všechna i tak se mi průběžně požírají některé členy a ve výsledku dostanu lineární rovnici jejíž řešení je $\beta = 0.5$.)
- 3) Nebudu vůbec řešit kvadratické rovnice tj. budu předpokládat $b_k \approx c_{k-1}$ ale zvolím β tak, aby b_k bylo co nejblíže c_{k-1} pro všechna k .

$$\hat{\beta} = \arg \min_{\beta} \sum_k (b_k - c_{k-1})^2$$

kde za b_k a c_k dosadíme výrazy obsahující číselná písmena.

Polus s $\beta = 0.2$: Průměr odchylky $|\beta - \hat{\beta}|$ pro různé metody:

SPA: 0.0077 (1): 0.0466 (2) k=50...50 sude: 0.0101 (3) k=50...50: 0.0056

Vkládání do paletových formátů


- 1) Změna uspořádání palety
+ není vůbec zkrát od pohledu na obrázek
 - omezení kapacity $\log_2(256!) \approx 1684$ bitů ≈ 210 bajtů
 - většina programů uspořádá paletu podle jasu nebo frekvence výskytu dané barvy v obrázku $\Rightarrow$ náhodně uspořádaná paleta je podzřelá.
 - otevření a opětovné uložení obrázku může vést k seřazení palety a ke ztrátě zprávy.

2) Vkládání do matice ukrytelnosti

- a) Paletu seřadíme podle jasu (a přeindexujeme matici ukrytelnosti).
Potom provedeme LSB embedding na ukrytelnosti. (EzSteg)
 - Problém: změna nejvyššího bitu sice nevadí, způsobem způsoben jas pixelu ale může vést ke změně barvy např. červen na zelenou.

- b) zvolíme sofistikovanější uspořádání palety, které minimalizuje vzdálenost mezi následujícími barvami v paletě.
po sobě

- Problem: NP-úplný (obchodní cestující).




c) Nebudeme vkládat do LSB

Ke každé barvě ^{v paletě} přiřadíme hodnotu 0 nebo 1 takovým způsobem, aby nejblížeší barva v paletě měla opačnou hodnotu.

Vkládání s optimální volbou parity

Pozn: Přiřazení parity nemusí být vyčíslené



• Algoritmus ^{optimální} volby parity

Vstup: Množina $\{c_i : i \in I\} \subseteq \{0, 1, \dots, 255\}^3$ (paleta). $I = \{0, 1, \dots, 255\}$ množina indexů.

Výstup: $p : I \rightarrow \{0, 1\}$,

$f : I \rightarrow I$ takové, že

$p(i) = 1 - p(f(i)) \quad \forall i \in I$

$\|c_i - c_{f(i)}\|_2$ nabývá minimální možnou hodnotu

Postup:

for each $i \in I$

$p(i) := \infty$

$E := \{(\|c_i - c_j\|_2, c_i, c_j) : i, j \in I, i \neq j\}$

Množinu E lze uspořádat lexicograficky, tj. především podle

vzdálenosti barev a potom podle barev jakožto 3-složkových vektorů.

while $E \neq \emptyset$

$(d, c_i, c_j) := \min_{\text{LEX}} E$ # $p(i) = \infty$. Pokud $p(i) \in \{0, 1\}$, barva c_i se odstraní
ze všech výskytů na druhé pozici.

if $p(j) = \infty$ ~~# ještě $p(j) = \infty$ poté $p(i) = \infty$~~

$p(i) := 0$

$p(j) := 1$

$f(i) := j$

$f(j) := i$

else

$E := E \setminus (\mathbb{R} \times \{i, j\} \times C)$ odstraní všechny $(\cdot, c_i, \cdot)$ a $(\cdot, c_j, \cdot)$

$p(i) := 1 - p(j)$

$f(i) := j$

$E := E \setminus (\mathbb{R} \times \{i\} \times C)$ odstraní všechny $(\cdot, c_i, \cdot)$

end if

done

• Algoritmus je deterministický a závisí jen na množině barev v paletě (nikoliv na jejím uspořádání)

• Doběhne: množina E se při každém průchodu zmenší.

• Funkce p i f jsou dobře definované

• Zřejmě platí $p(i) = 1 - p(f(i)) \quad \forall i \in I$

• $\|c_i - c_{f(i)}\|_2$ nabývá min možnou hodnotu.

$$\left(p(i) = \infty \Leftrightarrow (\cdot, c_i, \cdot) \in E \right)$$

• Algoritmus vkládání - s optimální volbou parity

Vstup: Nosič $x = (x_1, \dots, x_n) \in \mathbb{I}^n$ posloupnost indexů do palety.

Zpráva $z = (z_1, \dots, z_m) \in \{0, 1\}^m$

Klíč $\pi \in S_n$

Výstup: Stegoobjekt $y = (y_1, \dots, y_n) \in \mathbb{I}^n$

Postup: for each $i \in \{1, 2, \dots, m\}$

$$y_{\pi(i)} = \begin{cases} x_{\pi(i)} & \text{pokud } p(x_{\pi(i)}) = z_i \\ f(x_{\pi(i)}) & \text{pokud } p(x_{\pi(i)}) \neq z_i \end{cases}$$

for each $i \in \{m+1, \dots, n\}$

$$y_{\pi(i)} = x_{\pi(i)}$$

• Algoritmus extrakce

Vstup: Stegoobjekt $y = (y_1, \dots, y_n) \in \mathbb{I}^n$

Klíč $\pi \in S_n$

Délka zprávy m

Výstup: Zpráva $z = (z_1, \dots, z_m) \in \{0, 1\}^m$

Postup: for each $i \in \{1, \dots, m\}$

$$z_i = p(y_{\pi(i)})$$

• Efektivita vkládání:
$$e = \frac{E[\log_2 |M(x)|]}{E[d_2(x, y)]} = \frac{m}{E[d_2(x, y)]}$$

definujeme $h(i) := \#\{j \mid x_j = i\}$

$$E[d_2(x, y)] = \sum_{j=1}^n E[\|c_{x_j} - c_{y_j}\|^2] = \sum_{j=1}^n \underbrace{\frac{1}{2} \frac{m}{n}}_{\text{pravděpodobnost, že } j\text{-tý pixel bude změněn}} \underbrace{\sum_{i \in \mathbb{I}} \frac{h(i)}{n} \|c_i - c_{f(i)}\|^2}_{\text{očekávaná velikost změny}}$$

$$= \frac{m}{2} \sum_{i \in \mathbb{I}} \underbrace{\frac{h(i)}{n}}_{\text{relativní četnost barev i v obrazu}} \|c_i - c_{f(i)}\|^2$$

↑
vzdálenost k nejbližší barvě

efektivita
$$e = \frac{2}{\sum_{i \in \mathbb{I}} \frac{h(i)}{n} \|c_i - c_{f(i)}\|^2}$$

	# barev	
efektivita	255	23
barngif		
optpar	0.0228	0.0012
lumLSB	0.0019	0.0003
	12x	4x

Vkládání při redukci hloubky barev s optimální volbou parity

LSB 10

Vezmeme jako nosič 24-bitový rastrový obrázek a provedeme redukci hloubky barev s difuzí chyb, ovšem s tím rozdílem, že při zaobrazování na nejbližší barvu se u pixelů nesoucíh bitů zprávy omezíme na možnou barvu jejich parity odpovídá bitu zprávy.

Adaptivní vkládání

- Chceme vkládat bity zprávy do oblastí uniformní barvy jako např. nebe nebo přesvícené oblasti. Chceme vkládat do oblastí s vysokou texturou.
- Problém: Přijemce nemá k dispozici nosič, aby určil co je oblast s vysokou či nízkou texturou. (vkládání může texturu snížit)
- Příklad: - Obrázek rozdělíme na bloky velikosti 3×3 a definujeme funkci t , která měří texturu bloku, např.

$$t(B) = \# \text{ barev v } B.$$

- Do daného bloku vkládáme právě když jeho textura $t(B) > \gamma$, kde γ je nějaká vhodně zvolená prahová hodnota.
- Poté co provedeme vkládání do bloku, musíme texturu snížit znovu. Stane-li se, že textura klesne pod prahovou hodnotu, bude tento blok příjemcem ignorován. Bity proto musíme vložit znovu do následujícího bloku. Tímto se snižuje efektivita vkládání.

Barn23.gif: $\gamma = 2$... 53% pixelů použito
 $\gamma = 3$... 26% pixelů použito

Párová analýza paletových formátů

LSB11

Kvantitativní útok na EzStego

EzStego:

Máme paletový obrázek, paleta je seřazená podle jasu.

Nosič: $x \in \{0, 1, \dots, 255\}^n$ indexy do palety

$\beta = 1/2$ pravděpodobnost změny

Stegoobjekt $y \in \{0, 1, \dots, 255\}^n$

Zprvu ukládáme do LSB, čili opět

$\dots 2k, 2k+1, 2k+2, 2k+3, \dots$

Očekáváme, že v přirozeném nosiči se objeví posloupnosti stejné barvy. Tato vlastnost je ukládáním narušena.

Definice

k -tý barevný výřez $\varphi_k(c) := \begin{cases} 0 & \text{pro } c = 2k \\ 1 & \text{pro } c = 2k+1 \\ \varepsilon & \text{pro ostatní } c \end{cases}$
↑ prázdné slovo.

k -tý posunutý barevný výřez $\varphi'_k(c) := \begin{cases} 0 & \text{pro } c = 2k-1 \\ 1 & \text{pro } c = 2k \\ \varepsilon & \text{pro ostatní } c \end{cases}$

přirozeným způsobem rozšiřujeme na slova (posloupnosti) jako homomorfismus monoidů.

$$Z := \varphi_0(y) \parallel \varphi_1(y) \parallel \dots \parallel \varphi_{127}(y)$$

$$Z' := \varphi'_1(y) \parallel \varphi'_2(y) \parallel \dots \parallel \varphi'_{127}(y)$$

$$R(\beta) = \frac{\#\{i \mid z_i = z_{i+1}, 1 \leq i \leq n-1\}}{n-1}$$

Relativní počet homogenních párů v Z .

$R'(\beta)$ obdobně

Pr

$$y = \begin{matrix} & 0 & 1 & 1 & 2 & 3 & 1 & 2 & 2 \\ \varphi_0: & 0 & 1 & 1 & 2 & 3 & 1 & 2 & 2 \\ \varphi_1: & & & & & & & & \end{matrix} \rightsquigarrow Z = 0 \underline{1} \underline{1} \underline{1} 0 \underline{1} 0 \underline{0} \quad R(\beta) = \frac{3}{7}$$


$$\begin{matrix} & 0 & 1 & 1 & 2 & 3 & 1 & 2 & 2 \\ \varphi'_1: & & & & & & & & \\ & 0 & 0 & 1 & 0 & 1 & 1 & & \end{matrix} \rightsquigarrow Z' = \underline{0} \underline{0} 1 0 \underline{1} \underline{1} \quad R'(\beta) = \frac{2}{5}$$

- V nosiči očekáváme, že počty homogenních párů v neposunutých a posunutých výřezech budou stejné: $\boxed{R(0) = R'(0)} \quad (E[R(0) - R'(0)] = 0)$

- R je kvadratická funkce:

co se děje při ukládání:

$$E[R(\beta)] = R(0)((1-\beta)^2 + \beta^2) + (1-R(0))2\beta(1-\beta)$$



$R(0)$ je konstanta pro pevně zvolený nosič a $R(\beta)$ je tedy kvadratický polynom v proměnné β .

$$\boxed{E[R(\beta)] = E[R(1-\beta)]}$$

- $|R'(1-\beta)|$ zjistíme tak, že ve stegobjektu y obrátíme všechny LSB, spočítáme posunuté výřezy a určíme počet homogenních párů.

Pro to funguje:

máme $y = 01\boxed{2}\boxed{3}\boxed{1}22$, dejme tomu, že $\beta = \frac{3}{8}$ a

y vzniklo překlopením tří LSB, takže

$$x = 01\overset{\vee}{0}\overset{\vee}{2}\overset{\vee}{2}0\overset{\vee}{2}\overset{\vee}{2}$$

nyí simulujeme ~~co~~ co by se stalo kdyby $\beta = \frac{5}{8}$

$$\bar{y} = \underset{\substack{\uparrow \\ 4}}{1}\underset{\substack{\uparrow \\ 6}}{0}\underset{\substack{\uparrow \\ 8}}{0}32033 \quad R'(1-\beta) = \frac{0}{1} = 0$$

Nevíme sice β ani pozice, kde došlo k překlopení, ale překlopením všech hodnot simulujeme uložení s parametrem $1-\beta$.

- $|R(\frac{1}{2}) \approx \frac{1}{2}|$

Pro $\beta = \frac{1}{2}$ tvoří LSB vhodnou posloupnost.

Z je vlastně posloupnost LSB ať už trochu přepřerazovaná.

$P(z_i = z_{i+1}) = \frac{1}{2}$ pro libovolné i , $1 \leq i \leq n-1$

$$R(\frac{1}{2}) = \frac{\frac{1}{2}(n-1)}{n-1} \leftarrow \text{očekávaný počet homogenních párů.}$$

- $R(\frac{1}{2}) = ?$

Definujeme: $\psi_k(c) = \begin{cases} 0 & \text{pro } c \in \{2k-2, 2k-1\} \\ 1 & \text{pro } c \in \{2k, 2k+1\} \\ \varepsilon & \text{pro ostatní } c \end{cases}$

Pozorování:
 $\psi_k(x) = \psi_k(y)$

$$W := \psi_1(y) \parallel \psi_2(y) \parallel \dots \parallel \psi_{\lfloor n/2 \rfloor}(y)$$

- Je-li $\beta = \frac{1}{2}$, pak Z vznikne z W tak, že každý člen posloupnosti w buď vyhodíme nebo zachováme s pětí 50%.

$$\begin{array}{ccccccc} \psi_k & 0 & 0 & 1 & 1 & & \rightarrow w \\ & \uparrow & \uparrow & \uparrow & \uparrow & & \\ & \swarrow 0.5 & \swarrow 0.5 & \swarrow 0.5 & \swarrow 0.5 & & \\ & 2k-2 & 2k-1 & 2k & 2k+1 & & \\ \psi'_k & \downarrow & \downarrow & \downarrow & \downarrow & & \rightarrow z \\ & \swarrow 0.5 & \swarrow 0.5 & \swarrow 0.5 & \swarrow 0.5 & & \\ & \varepsilon & 0 & 1 & \varepsilon & & \end{array}$$

↓ prvky se vyjmají s 50% pravděpodobností.

- Ať $W = \dots w_i, \dots, w_k, \dots$ jestliže $w_i = w_{i+k}$, pak pravděpodobnost, že v Z utvoří homogenní pár je $(\frac{1}{2})^{k+1}$ tj. $\frac{1}{2}$ že w_i u zachováme a $(\frac{1}{2})^{k+1}$ že ty nezaviníme v páru.

- $\sum_{k=1}^{n/2} \frac{1}{2^{k+1}} \# \{i \mid w_i = w_{i+k}, 1 \leq i \leq n-k\}$ kde n je délka W.
očekávaný počet homogenních párů v Z

- Očekávaná délka Z je $\frac{n}{2}$.

$$R'(1/2) = \frac{1}{\frac{nw}{2}-1} \sum_{k=1}^{\frac{nw}{2}-1} \frac{1}{2^{k+1}} \# \{i | w_i = w_{i+k}, 1 \leq i \leq nw-k\} \quad \text{LSB 13}$$

kde nw je délka w .

- Praxe ukazuje, že $R'(\beta)$ lze dobře modelovat kvadratickým polynomem. (Důkaz ovšem neuvádíme.)

Předpokládejme tedy, že $f(\beta) := R(\beta) - R'(\beta)$ je kvadratický.

Známe $f(0) = R(0) - R'(0) \approx 0$.

$$f(1/2) = R(1/2) - R'(1/2) \approx 1/2 - R'(1/2)$$

$$f(\beta) = R(\beta) - R'(\beta)$$

$$f(1-\beta) = R(1-\beta) - R'(1-\beta) = R(\beta) - R'(1-\beta)$$

... technický postup ...

Polygon známe ve
dvou bodech $\Rightarrow$
redundance?

Nikoliv, některé body
jsou totiž závislé
na zbytečné β .

Odtud dostaneme kvadratickou rovnici $a\beta^2 + b\beta + c = 0$, kde

$$a = 2 - 4R'(1/2)$$

$\nwarrow$ (pozor, toto není f)

$$b = R'(\beta) - R'(1-\beta) - 2 + 4R'(1/2)$$

$$c = R(\beta) - R'(\beta)$$

Spočítáme $\hat{\beta} = \min(R_+, R_-)$. (Pro $\beta \approx 0.5$ můžeme vyjít komplexně.)

- Pozn obrázek můžeme načíst buď  anebo po Hilbertově



krivce: Tímto se zvyšuje pravděpodobnost, že zachytíme
uniformní oblast obrázku v posloupnosti

- Pozn Odhad opět vychází ± 0.05

Útok na ukládání s optimálním přirazením parity

OPTPAR
ATTACK
1

Idea: • 2 histogramu stegobrázku zrekonstruujeme histogramu nosiče pro různé hodnoty α .

- Jestliže α zvolíme větší má je jeho skutečná hodnota objevená se v zrekonstruovaném histogramu záporné hodnoty.
- Předpokládáme, že barvy v histogramu nemají monotonní rozdělení.

Pr:



Ukládání:

$$h(1) \doteq (1-\beta) h_0(1)$$

$$h(2) \doteq (1-\beta) h_0(2) + \beta \cdot h_0(1)$$

$$h(3) \doteq (1-\beta) h_0(3)$$

$$h(4) \doteq (1-\beta) h_0(4) + \beta(h_0(2) + h_0(3))$$

$$h_0(1) = 1000$$

$$h_0(2) = 10$$

$$\alpha = 0,2$$

$$\beta = 0,1 = \alpha/2 \text{ (pst. změny)}$$

⇓

$$h(1) \approx 900$$

$$h(2) \approx 9 + 100 = 109$$

Rekonstrukce:


$$h_0^{(1)}(1) \doteq \frac{1}{1-\beta} h(1)$$

$$h_0^{(1)}(2) \doteq \frac{1}{1-\beta} (h(2) - \beta \cdot h_0(1))$$

$$\doteq \frac{1}{1-\beta} (h(2) - \frac{\beta}{1-\beta} h(1)) \leftarrow$$

$$h_0^{(1)}(3) \doteq \dots$$

$$h_0^{(1)}(2) \approx \frac{1}{1-\beta} (109 - \frac{\beta}{1-\beta} 900)$$




Změny v histogramu při ukládání lze popsat maticově:

Definujeme $A = (a_{ij}) \in \mathbb{R}^{|\mathcal{C}| \times |\mathcal{C}|}$

$$a_{ij} = \begin{cases} 1 & \text{pokud } f(j) = i \\ 0 & \text{jinak} \end{cases}$$

Pr



$$A = \begin{pmatrix} 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 & 1 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix}$$

Vkládání

$$\vec{h} = \begin{pmatrix} h(1) \\ \vdots \\ h(|\mathcal{C}|) \end{pmatrix}$$

$$\vec{h}_0 = \begin{pmatrix} h_0(1) \\ \vdots \\ h_0(|\mathcal{C}|) \end{pmatrix}$$

$$\vec{h} = \beta \cdot A \cdot \vec{h}_0 + (1-\beta) \vec{h}_0$$

$$\vec{h} = (\beta \cdot A + (1-\beta) I) \vec{h}_0$$

Rekonstrukce

$$\vec{h}_0^{(\beta)} = (\beta \cdot A + (1-\beta)I)^{-1} \vec{h}$$

Úkol

$\forall \beta \in [0, 1]$ zrekonstruujeme histogram h_0 a definujeme


$$y(\beta) = \min_i h_0^{(\beta)}(i)$$

Za $\hat{\beta}$ zvolíme ~~hodnotu~~ maximální hodnotu $y(\beta)$ pro literu $y(\beta)$ mění
znaménko $+$ na $-$.
v intervalu ~~$[0, 1/2]$~~ $[0, 1/2]$

Potom $\hat{\beta}$ je horší odhad pravděpodobnosti změny.

$$(\hat{\alpha} = 2\hat{\beta})$$


Pozn $y(\beta)$ může mít tvar




Alternativní volba $\hat{\beta}$.

(Naše volba $\hat{\beta}$ jako maximálního
kořene je v souladu s výsledkem,
že se jedná o horší odhad β .)

Smyslem volby maximální hodnoty je odignorovat
případnou parabolu, protože ta se chová divně.
Viz Mathematica:



Toto není divné pro
to pro velké α selhává



Funguje dobře pro $\alpha < 0.5$

Když upevníme ~~jednoduchý~~ v jádrech, pak funguje dobře pro $\alpha > 0.5$